



PCT/CN03/00079

# 证 明

|                   |     |
|-------------------|-----|
| REC'D 02 APR 2003 |     |
| WIPO              | PCT |

本证明之附件是向本局提交的下列专利申请副本

申 请 日： 2002 04 23

申 请 号： 02 1 17283.8


申 请 类 别： 发明

发明创造名称： 基于基带数字预失真技术的提高射频功率放大器效率的方法

申 请 人： 华为技术有限公司

发明人或设计人： 龙茂林

**PRIORITY  
DOCUMENT**  
SUBMITTED OR TRANSMITTED IN  
COMPLIANCE WITH RULE 17.1(a) OR (b)



中华人民共和国  
国家知识产权局局长

王景川

2003 年 2 月 17 日

# 权 利 要 求 书

1、一种基于基带数字预失真技术的提高射频功率放大器效率的方法，包括：

(1) 根据需要确定建立神经网络的结构参数,并建立神经网络,输入建立射频功率放大器的神经网络模型所需要的建模数据和网络参数初始值；

(2) 利用输入的数据和网络参数进行前向传播，计算神经网络输出值与希望输出值的差值，并利用该差值沿上述神经网络进行后向传播，以对网络参数进行修正；

(3) 判断上述差值是否满足设定的条件，如果满足条件，则输出射频功率放大器的神经网络模型，并执行步骤(4)，否则，将修正后的网络参数输入神经网络，执行步骤(2)；

(4) 利用该神经网络模型求解出射频功率放大器的预失真算法；

(5) 将射频功率放大器的输入信号采用上述预失真算法进行预失真处理后，送入射频功率放大器。

2、根据权利要求1所述的基于基带数字预失真技术的提高射频功率放大器效率的方法，其特征在于所述的结构参数包括：输入信号的延迟项个数 $n$ 、神经网络中每层的神经元的个数 $r$ 、神经网络的层数 $m$ ；所述的建模数据包括射频功率放大器的输出信号 $Y(KT)$ 、输入信号及输入信号延迟项；所述的网络参数包括：权重 $W_{ijk}$ 和偏置 $b_{ij}$ ；所述的射频功率放大器的输出信号 $Y(KT)$ 为与输入信号对应的希望输出值，即与输入信号对应的射频功率放大器的实际输出值。

3、根据权利要求2所述的基于基带数字预失真技术的提高射频功率放大器效率的方法，其特征在于所述的输入信号及输入信号延迟项为：功率放大器的基带数字信号幅值 $X(KT)$ 及其延迟项 $X[(K-1)T] \dots X[(K-n+1)T]$ 。

4、根据权利要求3所述的基于基带数字预失真技术的提高射频功率放大器效率的方法，其特征在于所述的输入信号的延迟项个数 $1 < n < 10$ 、神经网络中每个层面的神经元的个数 $1 < r < 10$ 、神经网络的层面数 $1 < m < 10$ 。

5、根据权利要求2所述的基于基带数字预失真技术的提高射频功率放大器效率的方法，其特征在于所述的输入信号及输入信号延迟项为：功率放大器的基带数字信号幅值 $X(KT)$ 及其延迟项 $X[(K-1)T]$ 、 $X[(K-2)T]$ 、...、 $X[(K-n+1)T]$ 和基带数字信号相位 $Fin(KT)$ 及其延迟项 $Fin[(K-1)T]$ 、 $Fin[(K-2)T]$ 、...、 $Fin[(K-n+1)T]$ ，所述的输入信号延迟项个数包括基带数字信号幅值的延迟项个数 $n1$ 和基带数字信号相位的延迟项个数 $n2$ 。

6、根据权利要求5所述的基于基带数字预失真技术的提高射频功率放大器效率的方法，其特征在于所述的基带数字信号幅值的延迟项个数 $1 < n1 < 5$ 、基带数字信号相位的延迟项个数 $1 < n2 < 10$ 、神经网络中每层的神经元的个数 $1 < r < 10$ 、神经网络的层数 $1 < m < 10$ 。

7、根据权利要求2所述的基于基带数字预失真技术的提高射频功率放大器效率的方法，其特征在于所述的步骤（2）包括：



(71) 利用各层神经网络的网络参数 $W_{ijk}$ 计算出神经网络中相应的中间变量 $V_{ij}$ ;

(72) 通过中间变量 $V_{ij}$ 及神经元激活函数计算相应的网络各个神经元的输出值 $Y_{ij}$ ;

(73) 将神经网络最后一层神经元的输出值放大 $M$ 倍后即为神经网络的输出值 $Y_m(KT)$ ,  $M$ 取值大于功率放大器的饱和水平;

(74) 计算 $Y_m(KT)$ 与功率放大器的实际输出 $Y(KT)$ 的差值。

(75) 将 $Y_m(KT)$ 与 $Y(KT)$ 的差值 $e(kT)$ 放大 $-M$ 倍, 并利用最后一层网络的神经元输出值 $V_{ij}$ 计算出 $\Omega(V_{ij})$ , 其中,  $\Omega(v)=d\Psi(v)/dv$ ;

(76) 将 $Me(kT)$ 和 $\Omega(V_{ij})$ 相乘, 得 $\delta_{ij}$ 值;

(77) 变量 $\delta_{ij}$ 利用网络参数当前值沿着神经网络前向传播的通道进行后向传播, 并得到中间变量 $u_{i1}, u_{i2}, \dots, u_{ir}$ ;

(78) 利用 $u_{i1}, u_{i2}, \dots, u_{ir}$ 及当前网络参数计算出中间变量 $\delta_{i1}, \delta_{i2}, \dots, \delta_{ir}$ ;

其中: 利用神经网络中的中间变量 $v_{i1}, v_{i2}, \dots, v_{ir}$ 计算出的 $\Omega(V_{i1}), \Omega(V_{i2}), \dots, \Omega(V_{ir})$ 分别与 $u_{i1}, u_{i2}, \dots, u_{ir}$ 相乘即可得到 $\delta_{i1}, \delta_{i2}, \dots, \delta_{ir}$ ;

(79) 利用 $\delta_{i1}, \delta_{i2}, \dots, \delta_{ir}$ 更新当前网络参数, 并根据 $c=[S(\delta_{i1}^2 + \delta_{i2}^2 + \dots + \delta_{ir}^2) + \delta_{ij}^2]^{1/2}$ 计算出 $c$ 值;

其中: 更新当前网络参数时, 更新后的网络参数 $W_{ijk}$ 和 $b_{ij}$ 分别为:



$W_{ijk}$ 的值等于更新前的网络参数值减去  $\eta \times \delta_{ij} \times$  相应神经元的输出值,  $\eta$  为搜索步长;

$b_{ij}$ 的值为更新前的网络参数值减去  $\eta \times \delta_{ij}$ ;

8、根据权利要求7所述的基于基带数字预失真技术的提高射频功率放大器效率的方法, 其特征在于所述的步骤(3)为: 判断 $c$ 值是否符合要求, 如符合要求, 则输出射频功率放大器的神经网络模型, 否则, 将修正后的网络参数 $W_{ijk}$ 和 $b_{ij}$ 输入神经网络, 执行步骤(71)。

9、根据权利要求7所述的基于基带数字预失真技术的提高射频功率放大器效率的方法, 其特征在于所述的 $K$ 值为2倍的射频功率放大器平均增益 $k_b$ 。

10、根据权利要求2所述的基于基带数字预失真技术的提高射频功率放大器效率的方法, 其特征在于所述的输入信号的带宽大于射频功率放大器实际运行中的输入信号的带宽。

# 说明书

## 基于基带数字预失真技术的提高射频功率放大器效率的方法

### 技术领域

本发明涉及一种宽带无线通讯系统中提高射频功率放大器效率的方法，尤其涉及一种基于基带数字预失真技术的提高射频功率放大器效率的方法。

### 背景技术

射频带宽资源的有限性对特定用途的各类指定频带范围的射频发射机的带外频谱泄漏或邻道功率泄漏提出了严格的限制要求。由于射频功率放大器在接近饱和工作区的非线性特性使得在较大输入信号条件下其输出信号的频谱比输入信号的频谱要宽，即功率放大器的非线性特性造成带外频谱泄漏。因此，为了降低带外频谱泄漏或邻道功率泄漏，通信系统中的射频功率放大器一般工作在远离其饱和区的线性工作区。这样的处理方式使得射频功率放大器的效率非常低，同时该方法带来的散热问题使得功率放大器的结构比较庞大笨重，提高了功率放大器的成本。为了解决这一问题，目前比较有效的办法之一是基带数字预失真技术，实现这一技术的首要步骤则是建立一个便于求解预失真算法的射频功率放大器的数学模型。

为了解决单纯的带外频谱泄漏的问题，数字移动通信系统中的基带数字预失真技术是近年来针对此类问题产生的新技术，其目的在于同时解决射频功率放大器的带外频谱泄漏和低效率问题。基带数字预失真技术的主要思想是对进入射频功率放大器的信号 $X$ 进行预先的处理得到 $Xy$ ，使得

Xy经过射频功率放大器放大后所得到的输出信号Y与原始输入信号X之间呈现线性的关系,当经过预失真技术线性化后的射频功率放大器的输入X与输出Y之间呈现线性关系时,提升输出功率便不会造成带外频谱泄漏.由于预失真是通过对基带数字信号进行预处理来实现,所以图1中的射频功率放大器实际上代表着包括射频功率放大器在内的整个从基带到载波(上变频)再从载波到基带(用于信号反馈的下变频)的整个射频传输通道。

为了求解图1中的“预失真”算法,我们首先必须知道射频功率放大器的数学模型,而且这个数学模型必须是针对预失真求解而建立的,用于预失真技术的数学模型需要尽可能的减少整个预失真系统实现时的计算量和所需内存容量。针对这一目的的射频功率放大器的数学模型,通常采用的是黑箱模型,即模型反映的是对象(射频功率放大器)的输入输出关系,如图2所示,图2中射频功率放大器的输出Y与模型的输出 $Y_m$ 之间的差e被用来对模型进行调整或修正。当e达到零时,模型便准确代表射频功率放大器的输入输出特性。实际建立模型过程中,当e足够小时,就可以认为模型已经能够以一定的精度代表射频功率放大器的输入输出关系。

通常,射频功率放大器的输入X与输出Y之间的关系包含基带数字信号X和Y的幅值( $|X|$ 和 $|Y|$ )和相位( $\Phi_{in}$ 和 $\Phi_{out}$ )这两个方面的内容,其中输入幅值 $|X|$ 与输出幅值 $|Y|$ 之间的关系被称为射频功率放大器的AM-AM模型:

$$|Y|=f(|X|). \quad (1)$$

而输入幅值 $|X|$ 与输入输出相位偏移 $\Delta\Phi$ 之间的关系则被称为AM-PM模型:

$$\Delta\Phi=g(|X|), \quad (2)$$

其中  $\Delta\Phi = \Phi_{\text{out}} - \Phi_{\text{in}}$ 。

但是，对于宽带系统，至今未见有人成功研究过AM-PM模型，甚至连典型的AM-PM曲线该是什么形状都是众说纷纭，文献里的AM-PM曲线大多是信手勾出的图形，毫无可靠性，且没有实验数据支持。

目前，对射频功率放大器模型的研究主要工作都集中在建立射频功率放大器的AM-AM模型方面。其中，针对射频功率放大器输入输出幅值关系（即AM-AM模型）的一种典型的多项式模型（取自加拿大PMC公司的PCT专利：WO 01/05026 A1）结构中包含了一些输入信号的延迟项；该模型可以用来描述射频功率放大器输入输出幅值方面的饱和及迟滞环（或称记忆）等非线性特性。但该多项式模型仍然存在以下缺点：

- 1、多项式模型的参数估计涉及的计算量比较大，且随着阶数的增大，对应的计算量呈指数增加。

- 2、用多项式方法获得射频功率放大器的AM-AM模型后，对应这一多项式模型的预失真算法的求解难度比较大，特别是因为模型精度要求而不得不采用阶数较高的多项式模型时，其对应的用于预失真的逆函数的解析解很难求得，而采用数值方法求解时其计算量随着多项式的阶数的增大会呈非线性迅速增加。

- 3、在自适应预失真系统中，射频功率放大器模型本身需要存储在控制器内，并需在线计算对应射频功率放大器输入模型输出量以便在线更新模型和更新自适应预失真器的预失真参数。而多项式方法的射频功率放大器模型的存储需要较大的存储空间。这是因为，在多项式方法中，模型



的阶数每增加一阶，不仅模型中参数的个数增加，更重要的是同时引入的一组新的指数函数（组中函数的个数取决于模型中延迟项的数目）。在存储模型时，这些新增加的参数是需要存储的，而且还需要增加一组对应的表格来存储这些指数函数（或者需要使用乘法器），使得模型本身的存储所需的空间不断增大。

4、多项式方法的AM-AM模型已经得到应用，但在AM-PM模型方面，虽然人们作出了不断的努力，至今还没有这方面的成功实例。且现有文献中强行把输入幅值与输入输出相位偏移孤立地联系起来（即AM-PM模型）的基础是值得怀疑的。

#### 发明内容

本发明的目的是提供一种基于基带数字预失真技术的提高射频功率放大器效率的方法，以降低射频功率放大器工作时的带外频谱泄漏，并可有效提高射频功率放大器的效率。

本发明的目的是这样实现的：基于基带数字预失真技术的提高射频功率放大器效率的方法，包括：

（1）根据需要确定建立神经网络的结构参数，并建立神经网络，输入建立射频功率放大器的神经网络模型所需要的建模数据和网络参数初始值；

（2）利用输入的数据和网络参数进行前向传播，计算神经网络输出值与对应的希望输出值的差值，再利用该差值沿上述神经网络进行后向传播，以修正网络参数；

(3) 判断上述差值是否满足设定的条件, 如果满足条件, 则输出射频功率放大器的神经网络模型, 并执行步骤(4), 否则, 将修正后的网络参数输入神经网络, 执行步骤(2);

(4) 利用该神经网络模型求解出射频功率放大器的预失真算法;

(5) 将射频功率放大器的输入信号采用上述预失真算法进行预失真处理后, 送入射频功率放大器。

所述的结构参数包括: 输入信号的延迟项个数 $n$ 、神经网络中每层的神经元的个数 $r$ 、神经网络的层数 $m$ ; 所述的建模数据包括功率放大器的输出信号 $Y(KT)$ 、输入信号及输入信号延迟项; 所述的网络参数包括: 权重 $W_{ijk}$ 和偏置 $b_{ij}$ ; 所述的射频功率放大器的输出信号 $Y(KT)$ 为与输入信号对应的希望输出值, 即与输入信号对应的射频功率放大器的实际输出值。

所述的输入信号及输入信号延迟项为: 功率放大器的基带数字信号幅值 $X(KT)$ 及其延迟项 $X[(K-1)T] \dots X[(K-n+1)T]$ 。

所述的输入信号的延迟项个数 $1 < n < 10$ 、神经网络中每个层面的神经元的个数 $1 < r < 10$ 、神经网络的层面数 $1 < m < 10$ 。

所述的输入信号及输入信号延迟项为: 功率放大器的基带数字信号幅值 $X(KT)$ 及其延迟项 $X[(K-1)T]$ 、 $X[(K-2)T]$ 、...、 $X[(K-n+1)T]$ 和基带数字信号相位 $\text{Fin}(KT)$ 及其延迟项 $\text{Fin}[(K-1)T]$ 、 $\text{Fin}[(K-2)T]$ 、...、 $\text{Fin}[(K-n+1)T]$ , 所述的输入信号延迟项个数包括基带数字信号幅值的延迟项个数 $n_1$ 和基带数字信号相位的延迟项个数 $n_2$ 。

所述的基带数字信号幅值的延迟项个数 $1 < n_1 < 5$ 、基带数字信号相位的延迟项个数 $1 < n_2 < 10$ 、神经网络中每层的神经元的个数 $1 < r < 10$ 、神经网络的层数 $1 < m < 10$ 。

所述的步骤(2)包括:

(71) 利用各层神经网络的网络参数 $W_{ijk}$ 计算出神经网络中相应的中间变量 $V_{ij}$ ;

(72) 通过中间变量 $V_{ij}$ 及神经元激活函数计算相应的网络各个神经元的输出值 $Y_{ij}$ ;

(73) 将神经网络最后一层神经元的输出值放大 $M$ 倍后即为神经网络的输出值 $Y_m(KT)$ ,  $M$ 取值大于功率放大器的饱和水平;

(74) 计算 $Y_m(KT)$ 与功率放大器的实际输出 $Y(KT)$ 的差值。


(75) 将 $Y_m(KT)$ 与 $Y(KT)$ 的差值 $e(kT)$ 放大 $-M$ 倍, 并利用最后一层网络的神经元输出值 $V_{ij}$ 计算出 $\Omega(V_{ij})$ , 其中,  $\Omega(v) = d\Psi(v)/dv$ ;

(76) 将 $Me(kT)$ 和 $\Omega(V_{ij})$ 相乘, 得 $\delta_{ij}$ 值;

(77) 变量 $\delta_{ij}$ 利用网络参数当前值沿着神经网络前向传播的通道进行后向传播, 并得到中间变量 $ui_1, ui_2, \dots, uir$ ;

(78) 利用 $ui_1, ui_2, \dots, uir$ 及当前网络参数计算出中间变量 $\delta_{i1}, \delta_{i2}, \dots, \delta_{ir}$ ;

其中: 利用神经网络中的中间变量 $vi_1, vi_2, \dots, vir$ 计算出的 $\Omega(V_{i1}), \Omega(V_{i2}), \dots, \Omega(V_{ir})$ 分别与 $ui_1, ui_2, \dots, uir$ 相乘即可得到 $\delta_{i1}, \delta_{i2}, \dots, \delta_{ir}$ ;



(79) 利用  $\delta_{i1}, \delta_{i2}, \dots, \delta_{ir}$  更新当前网络参数, 并根据  $c = [S(\delta_{i1}^2 + \delta_{i2}^2 + \dots + \delta_{ir}^2) + \delta_{ij}^2]^{1/2}$  计算出  $c$  值;

其中: 更新当前网络参数时, 更新后的网络参数  $W_{ijk}$  和  $b_{ij}$  分别为:

$W_{ijk}$  的值等于更新前的网络参数值减去  $\eta \times \delta_{ij} \times$  相应神经元的输出值,  $\eta$  为搜索步长;

$b_{ij}$  的值为更新前的网络参数值减去  $\eta \times \delta_{ij}$ ;


所述的步骤 (3) 为: 判断  $c$  值是否符合要求, 如符合要求, 则输出射频功率放大器的神经网络模型, 否则, 将修正后的网络参数  $W_{ijk}$  和  $b_{ij}$  输入神经网络, 执行步骤 (71)。

所述的  $K$  值为 2 倍的射频功率放大器平均增益  $k_b$ 。

所述的输入信号的带宽大于射频功率放大器实际运行中的输入信号的带宽。

由上述技术方案可以看出, 本发明中提出一种新的面向基带数字预失真的射频功率放大器建模方法, 即神经网络方法。其中包括针对射频功率放大器输入输出幅值关系的 AM-AM 模型的神经网络方法和针对射频功率放大器相位偏移模型的神经网络方法, 以及这些方法中神经网络模型的结构设计及其参数估计。本发明中所应用的神经网络方法建立射频功率放大器数学模型, 其计算量随着模型复杂程度的增加而基本上呈线性增加, 且该神经网络模型特别适合于预失真算法的求解。

同时, 因该模型中唯一的非线性函数是其激活函数, 实现相应的自适应数字预失真系统时只需要一个表格来存放这个非线性函数, 模型存储时



所需的空間較小，且增加該模型複雜度時，要求的存儲空間增加不大，只需存放新增加的网络参数即可，而不增加非线性函数的种类和个数；本发明中所涉及的相位偏移模型将输入输出相位偏移与输入幅值和输入相位及其延迟项同时关联起来，从而建立起更加可靠和可行的射频功率放大器相位偏移模型，该相位偏移模型把外部可能对相位偏移造成影响的全部因素都考虑在模型的输入变量中，因而是一个比传统的AM-PM模型更加完备的关于射频功率放大器输入输出相位偏移的模型。

因此，本发明实现了通过建立精确的射频功率放大器的数学模型以提高功率放大器效率的发明目的。

#### 附图说明

图1为实现提高功率放大器效率的示意图；

图2为建立射频功率放大器模型的示意图；

图3 为针对射频功率放大器输入输出幅值关系的AM-AM模型示意图；


图4 为建立射频功率放大器的AM-AM模型所应用的神经网络模型示意图；

图5 为建立射频功率放大器的AM-AM模型计算流程图；

图6 为针对建立针对射频功率放大器相位偏移模型的神经网络建模方法；

图7 为实际射频功率放大器的AM—AM特性示意图；

图8 为建模信号的特性示意图；



17

图9 为模型验证信号的特性示意图；

图10 为模型验证结果示意图。

### 具体实施方式

本发明所提供的基于基带数字预失真技术的提高射频功率放大器效率的方法是通过通过对射频功率放大器的输入信号进行预失真处理，以增大其工作范围，从而提高射频功率放大器的效率；对输入信号做什么样的预处理则需要根据功率放大器的数学模型来确定，本发明正是通过提供一种精确建立射频功率放大器的数学模型来提高功率放大器的效率，本发明中所涉及的是一种面向基带数字预失真技术的射频功率放大器的建模方法，即神经网络方法，分别包括如图3所示的针对射频功率放大器输入输出幅值关系的AM-AM模型的神经网络建模方法和如图6所示的针对建立射频功率放大器相位偏移模型的神经网络建模方法，以及这些方法中所包括的神经网络模型的结构设计及其参数估计。

下面将结合图4和图5进一步说明通过建立射频功率放大器的AM-AM模型的方法提高功率放大器的效率的具体实施方式。

步骤1：根据需要确定建立神经网络的结构参数，并建立神经网络，输入建立射频功率放大器的神经网络模型所需要的建模数据和网络参数初始值；

结构参数包括：输入信号的延迟项个数 $n$ 、神经网络中每层的神经元的个数 $r$ 、神经网络的层数 $m$ ；所述的建模数据包括射频功率放大器的输出信号 $Y(KT)$ 、输入信号及输入信号延迟项，射频功率放大器的输出信号

$Y(KT)$  为与输入信号对应的射频功率放大器的实际输出值，输入信号及输入信号延迟项为：功率放大器的基带数字信号幅值  $X(KT)$  及其延迟项  $X[(K-1)T] \dots X[(K-n+1)T]$ ；所述的网络参数包括：权重  $W_{ijk}$  和偏置  $b_{ij}$ ；

其中，神经网络模型的结构参数选取原则为：输入信号的延迟项个数  $1 < n < 10$ 、神经网络中每个层面的神经元的个数  $1 < r < 10$ 、神经网络的层面数  $1 < m < 10$ ；

基带数字信号函数中的  $K$  值为 2 倍射频功率放大器增益  $K_b$ ，如图 7 所示，根据实际射频功率放大器的测量数据作出其 AM—AM 特性曲线， $K_b$  为线性部分的大致平均增益；

如图 4 所示的神经网络中的网络参数分别为： $r=3$ ， $m=2$ ， $n=9$ ；另选定  $K=10$ ；为网络参数  $w_{ijk}$  和  $b_{ij}$  选定初始值  $w_{ijk}(0)$  和  $b_{ij}(0)$ ，输入神经网络；并将  $x(10T)$  输入到神经网络的  $x_m(kT)$ ，而  $x(9T)$  输入到  $x_m[(k-1)T]$ ， $x(8T)$  输入到  $x_m[(k-2)T]$ ， $x(7T)$  输入到  $x_m[(k-3)T]$ ， $\dots$ ， $x(T)$  输入到  $x_m[(k-9)T]$ 。

建立神经网络并输入相应的建模数据和网络参数后，便可利用输入的数据和网络参数进行前向传播，计算神经网络输出值，再利用该输出值与输入信号所对应的希望输出值的差值沿上述神经网络进行后向传播，以修正网络参数，希望输出值即为所输入的建模数据中的射频功率放大器的输出值  $Y(KT)$ ；

步骤 2：并利用各层神经网络的网络参数  $W_{ijk}$ 、输入信号及输入信号延迟项计算出神经网络中相应的中间变量  $V_{ij}$ ；



即计算出图4所示的神经网络中的V11、V12、V13，其中：

$$V11 = W111 \times X_m(KT) + W121 \times X_m[(K-1)T] + \dots + W1,10,1 \times X_m[(K-9)T] + b11;$$

$$V12 = W112 \times X_m(KT) + W122 \times X_m[(K-1)T] + \dots + W1,10,2 \times X_m[(K-9)T] + b12;$$

$$V13 = W113 \times X_m(KT) + W123 \times X_m[(K-1)T] + \dots + W1,10,3 \times X_m[(K-9)T] + b13。$$

步骤3：将中间变量 $V_{ij}$ 作为自变量，利用神经元激活函数计算相应的网络各个神经元的输出值 $Y_{ij}$ ；神经网络的中间层面上的神经元输出值 $Y_{ij}$ 作为下一级层面上的神经元的输入值，并可利用该值计算相应的中间变量 $V_{ij}$ 的值

计算过程中所采用的激活函数为： $\Psi(v) = (1 - e^{-kv}) / (1 + e^{-kv})$ ;

将上述计算出的V11、V12、V13作为自变量，分别计算出图4中的Y11、Y12、Y13的值，再利用计算出的Y11、Y12、Y13的值进一步计算V21的值， $V21 = W211 \times Y11 + W221 \times Y12 + W231 \times Y13 + b21$ ，最后将V21作为自变量，利用激活函数计算出Y21的值。

步骤4：将神经网络最后一层神经元的输出值Y21放大M倍后即为神经网络的输出值 $Y_m(KT)$ ，M取值必须大于射频功率放大器的饱和水平；

步骤5：计算 $Y_m(KT)$ 与功率放大器的实际输出 $Y(KT)$ 的差值 $e(KT)$ ，图4中的第一次前向传播过程所计算出的是 $e(10T)$ 的值。

至此，已经完成了沿神经网络的一次前向传播过程。





步骤6: 利用上述的 $e(10T)$ 的值进行沿神经网络的后向传播过程;  
将 $e(10T)$ 放大 $M$ 倍, 并利用最后一层网络的神经元输出值 $V_{ij}$ 计算出 $\Omega(V_{ij})$ , 其中,  $\Omega(v)=d\Psi(v)/dv$ ;

如图4中, 利用上述计算出的 $V_{21}$ 值计算出 $\Omega(V_{21})$ 的值;

并将 $-Me(kT)$ 和 $\Omega(V_{ij})$ 相乘, 计算出 $\delta_{ij}$ 的值; 即计算出图4中的 $\delta_{21}=\Omega(V_{21})\times Me(10T)$ ;

变量 $\delta_{ij}$ 利用网络参数当前值沿着神经网络前向传播的通道进行后向传播, 并得到中间变量 $ui_1, ui_2, \dots, uir$ ; 即利用当前的网络参数计算出图4中的 $u_1, u_2, u_3$ 的值;

然后, 利用 $ui_1, ui_2, \dots, uir$ 及当前网络参数计算出中间变量 $\delta_{i1}, \delta_{i2}, \dots, \delta_{ir}$ ;

其中: 利用神经网络中的中间变量 $vi_1, vi_2, \dots, vir$ 计算出的 $\Omega(V_{i1}), \Omega(V_{i2}), \dots, \Omega(V_{ir})$ 分别与 $ui_1, ui_2, \dots, uir$ 相乘即可得到 $\delta_{i1}, \delta_{i2}, \dots, \delta_{ir}$ ;

利用 $\delta_{i1}, \delta_{i2}, \dots, \delta_{ir}$ 更新当前网络参数, 并根据 $c=[S(\delta_{i1}^2 + \delta_{i2}^2 + \dots + \delta_{ir}^2) + \delta_{ij}^2]^{1/2}$ 计算出 $c$ 值;

其中: 更新当前网络参数时令更新后的网络参数 $W_{ijk}$ 和 $b_{ij}$ 分别为,  
 $W_{ijk}$ 的值等于更新前的网络参数值减去 $\eta \times \delta_{ij} \times$ 相应神经元的输出值,  $\eta$ 为搜索步长;

$b_{ij}$ 的值为更新前的网络参数值减去 $\eta \times \delta_{ij}$ ;

如图4所示，利用前面的前向传播中已经得到的 $v_{11}$ ， $v_{12}$ ， $v_{13}$ 的值计算 $\Omega(v_{11})$ ， $\Omega(v_{12})$ ， $\Omega(v_{13})$ ，将 $\Omega(v_{11})$ ， $\Omega(v_{12})$ ， $\Omega(v_{13})$ 与 $u_1$ ， $u_2$ ， $u_3$ 分别相乘，得到 $\delta_{11}$ ， $\delta_{12}$ ， $\delta_{13}$ ；并利用上述的 $\delta_{21}$ 更新第二层的网络参数 $w_{211}(0)$ ， $w_{221}(0)$ ， $w_{231}(0)$ ， $b_{21}(0)$ ，具体计算过程如下：

$$w_{211}(1) = w_{211}(0) - \eta \times \delta_{21} \times y_{11}(0)$$

$$w_{221}(1) = w_{221}(0) - \eta \times \delta_{21} \times y_{12}(0)$$

$$w_{231}(1) = w_{231}(0) - \eta \times \delta_{21} \times y_{13}(0)$$

$$b_{21}(1) = b_{21}(0) - \eta \times \delta_{21}$$

其中， $\eta$ 为搜索步长，需根据具体情况调整其取值。

利用得到的 $\delta_{11}$ ， $\delta_{12}$ ， $\delta_{13}$ 更新第一层的网络参数 $w_{111}(0)$ ， $w_{112}(0)$ ， $w_{113}(0)$ ， $b_{11}(0)$ ， $w_{121}(0)$ ， $w_{122}(0)$ ， $w_{123}(0)$ ， $b_{12}(0)$ ， $w_{131}(0)$ ， $w_{132}(0)$ ， $w_{133}(0)$ ， $b_{13}(0)$ ，...，等等，具体更新过程如下：

$$w_{111}(1) = w_{111}(0) - \eta \times \delta_{11} \times x_m(10T)$$

$$w_{121}(1) = w_{121}(0) - \eta \times \delta_{11} \times x_m(9T)$$

$$w_{131}(1) = w_{131}(0) - \eta \times \delta_{11} \times x_m(8T)$$

.....

$$w_{1,10,1}(1) = w_{1,10,1}(0) - \eta \times \delta_{11} \times x_m(T)$$

$$b_{11}(1) = b_{11}(0) - \eta \times \delta_{11}$$

$$w_{112}(1) = w_{112}(0) - \eta \times \delta_{12} \times x_m(10T)$$

$$w_{122}(1) = w_{122}(0) - \eta \times \delta_{12} \times x_m(9T)$$

$$w_{132}(1) = w_{132}(0) - \eta \times \delta_{12} \times x_m(8T)$$

.....

$$w_{1,10,2}(1) = w_{1,10,2}(0) - \eta \times \delta_{12} \times x_m(T)$$

$$b_{21}(1) = b_{21}(0) - \eta \times \delta_{12}$$

$$w_{113}(1) = w_{113}(0) - \eta \times \delta_{13} \times x_m(10T)$$

$$w_{123}(1) = w_{123}(0) - \eta \times \delta_{13} \times x_m(9T)$$

$$w_{133}(1) = w_{133}(0) - \eta \times \delta_{13} \times x_m(8T)$$

.....

$$w_{1,10,3}(1) = w_{1,10,3}(0) - \eta \times \delta_{13} \times x_m(T)$$

$$b_{31}(1) = b_{31}(0) - \eta \times \delta_{13}$$

其中， $\eta$ 为搜索步长，需根据具体情况调整其取值。

同时计算出图4所示神经网络中的 $c = (\delta_{11}^2 + \delta_{12}^2 + \delta_{13}^2 + \delta_{21}^2)^{1/2}$ 值。



步骤7：判断 $c$ 值是否符合要求，如符合要求，执行步骤8，否则，将调整后的网络参数 $W_{ijk}$ 和 $b_{ij}$ 输入神经网络，并令 $K=K+1$ ，即在图4所示的神经网络中令 $K=11$ ，然后，执行步骤2；

如果 $c$ 的值足够小了，则学习过程停止，模型训练完成。符合要求的 $c$ 值可视训练过程中模型的收敛情况具体决定。起始阶段则可以设定固定的迭代次数作为训练过程终止的条件。

步骤8：输出射频功率放大器的神经网络模型，执行步骤9。

步骤9：利用该神经网络模型求解出射频功率放大器的预失真算法；

步骤10：将射频功率放大器的输入信号采用上述预失真算法进行预失真处理后，送入射频功率放大器。

经过上述过程即可建立针对射频功率放大器输入输出幅值关系的精确的射频功率放大器的AM-AM神经网络模型，并应用该模型求解射频功率放大器的预失真算法，以实现提高射频功率放大器工作的目的。我们还可以通过建立针对射频功率放大器相位偏移的射频功率放大器神经网络模型，求解射频功率放大器的预失真算法，以提高射频功率放大器的效率。当建立针对射频功率放大器相位偏移的射频功率放大器神经网络模型时，神经网络的结构如图6所示，神经网络的输入信号及输入信号延迟项为：功率放大器的基带数字信号幅值 $X(KT)$ 及其延迟项 $X[(K-1)T]$ 、 $X[(K-2)T]$ 、...、 $X[(K-n+1)T]$ ，以及基带数字信号相位 $\Phi_{in}(KT)$ 及其延迟项 $\Phi_{in}[(K-1)T]$ 、 $\Phi_{in}[(K-2)T]$ 、...、 $\Phi_{in}[(K-n+1)T]$ ，输入信号延迟项个数



则包括基带数字信号幅值的延迟项个数 $n_1$ 和基带数字信号相位的延迟项个数 $n_2$ 。

建立针对射频功率放大器相位偏移的神经网络模型时，基带数字信号幅值的延迟项个数 $1 < n_1 < 5$ 、基带数字信号相位的延迟项个数 $1 < n_2 < 10$ 、神经网络中每层的神经元的个数 $1 < r < 10$ 、神经网络的层数 $1 < m < 10$ ；而且，此时 $K$ 的取值为： $K=1$ ， $M$ 的取值为： $M >$ 最大的输入输出相位偏移值（即大于 $\max \Delta \Phi$ ）。

建立针对射频功率放大器相位偏移的神经网络模型的计算过程则与建立针对输入输出幅值关系的AM-AM神经网络模型的计算过程原理相同。

本发明中所提供的针对射频功率放大器输入输出相位偏移模型的神经网络建模方法相对于传统AM-PM模型的优势是显而易见的。传统的AM-PM模型简单地把输入信号的幅值与相位偏移联系起来，没有考虑到输入信号的相位的大小以及输入信号的幅值的变化速率和输入信号的相位的变化速率对输入输出之间的相位偏移的影响。而我们设计的神经网络相位偏移模型中，通过在其输入端引入射频功率放大器的输入幅值及其延迟项和射频功率放大器的输入相位及其延迟项而考虑了全部外部因素可能对射频功率放大器的基带相位偏移的作用。

建立上述两种类型的射频功率放大器数学模型的建模过程中所使用的射频功率放大器的输入输出建模数据中，输入信号的带宽必须大于这些模型对应的射频功率放大器实际运行中的输入信号的带宽，以保证所建立的射频功率放大器数学模型具有足够的精度。即如果射频功率放大器对应的



CDMA或WCDMA系统运行时的带宽为 $kF$ （其中 $k$ 为整数， $F$ 为单个载波的带宽），那么，我们对建模信号的带宽 $F_m$ 的设计原则是：

$$F_m > kF.$$

其中，带外至少需一个载波的附加带宽。且建模信号的幅值和/或相位偏移大小需要足够大，以使用充分的数据量覆盖射频功率放大器实际运行时的情况。

本发明中的射频功率放大器神经网络输入输出幅值模型的建模方法已经利用实验数据经过建模验证。采用的是5MHz带宽的建模信号，如图8所示，对根据相应建模原则建立的神经网络输入输出幅值模型进行训练，即建模，而用另一个1.25MHz带宽的信号，如图9所示，用于作模型检验；所得到的结果如图10所示，其中几乎看不到模型数据与射频功率放大器实际数据之间的差别。而且，利用这个模型可以非常便利地求解对应的预失真算法，其求解难易程度不会象多项式建模方法那样随着模型规模的增大而恶化，求解了预失真算法后，便可以利用该预失真算法实现提高射频功率放大器效率的目的。




图 1




图 2




图 3

27

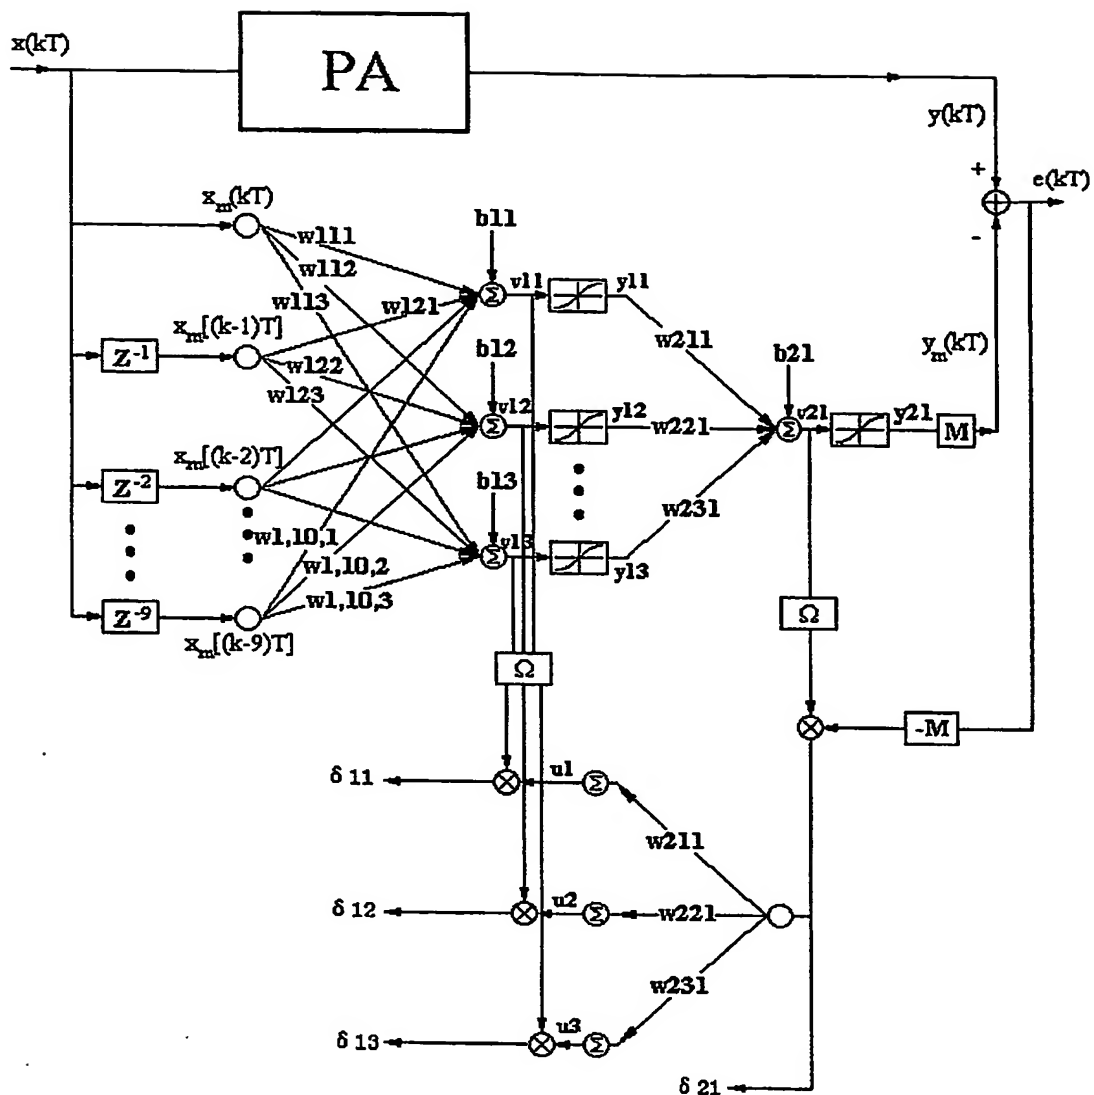


图 4



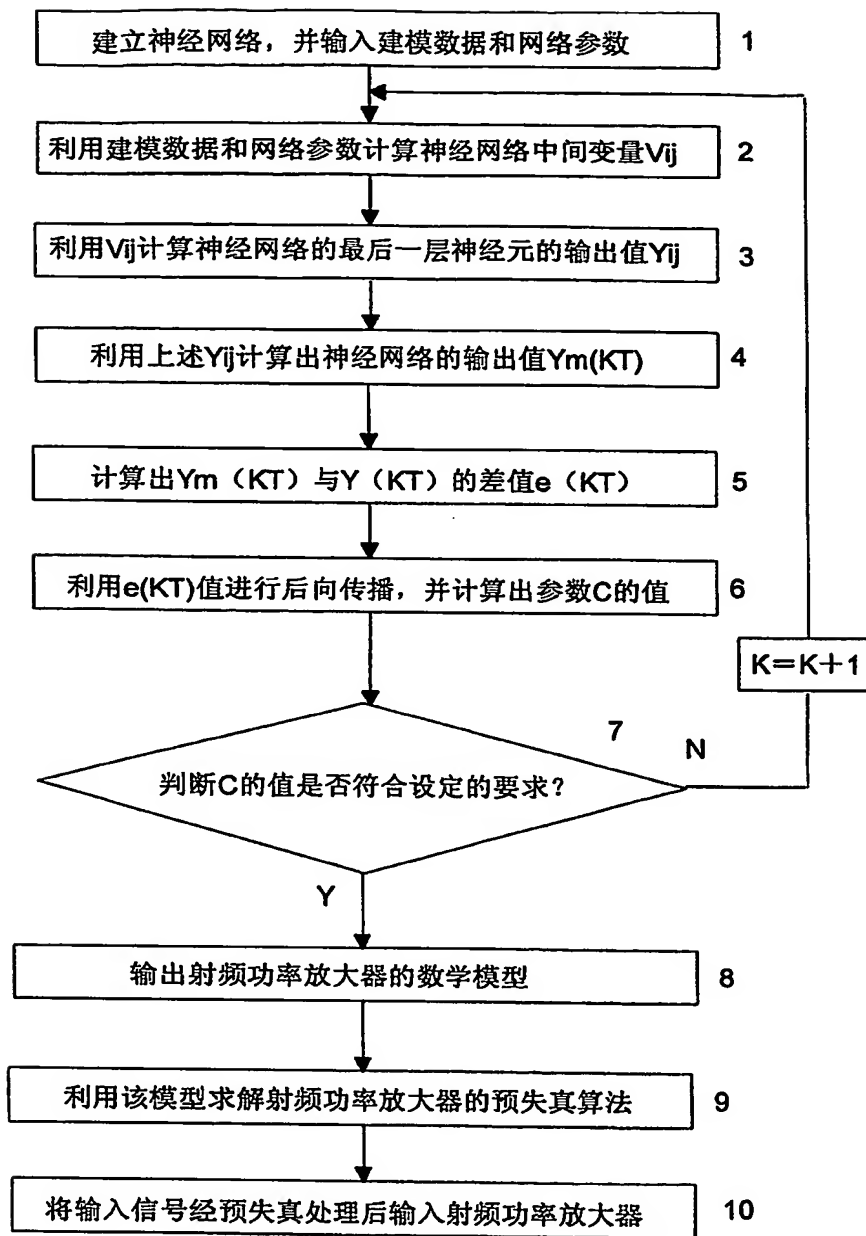


图 5




图 6  
Sig1: AM-AM




图 7




图 8




图 9




图 10